

1.1 Figure 1 et Figure 3 sont identiques parce que dans ce cas, quand  $p_i$  prend le minimum, on a  $p_i + P(w_i|x) = P(x)$ , c'est à dire  $P(w_i|x)$  prend le maximum, et de plus  $P(w_i|x) * P(x) = P(x|w_i) * P(w_i)$  avec  $P(w_i) = 1/C$ , alors  $P(x|w_i)$  prend le maximum, c'est le cas de  $\mu$  et  $\Gamma$  connue, Donc ces deux discriminateurs sont équivalent, les deux figures sont même. Pour la figure 13, dans les images de  $P(w_i|x)$ , ses frontières de la partie jaune (possibilité haute) représentent la frontière de discriminateur, la sommation des parties jaunes est la square ensemble. Pour les images de  $P(x|w_i)$ , ça signifie que si  $x$  appartient à  $w_i$ , il est plus possible d'apparaître dans les cercles (jaunes, verts) concentriques de possibilité. Les images dans Figure 13 sont accordé avec Figure 1 et Figure 3.

1.2 Si on présente le nombre dans la matrice sont  $N_{i,j}$ , alors

$$P(w_i|w_j) = P(w_i, w_j) / P(w_j) = N_{i,j} / (N_{1,j} + N_{2,j} + \dots + N_{c,j})$$

1.3 On observe que  $N_{1,2}$  devient 0 et  $N_{2,1}$  devient très grand, et la surface est plus proche de class  $C_1$  qu'avant. Le raison est  $a_{1,2}$  est très grand,  $P(w_1|w_2)$  a une importante contribution au  $R$ , alors, il faut  $P(w_1, w_2)$  être très petit, c'est à dire  $N_{1,2}$  devient très petit. Pour réaliser ça, il faut diminuer le point réel de class  $C_2$ , mais estime comme class  $C_1$ , donc la surface est plus proche de class  $C_1$  pour inclure plus de points réels de class  $C_2$ . En bref,  $a_{1,2}$  est grand signifie que si on juge  $x$  de  $w_2$  (vrai) à  $w_1$  (faux), le coût est grand. Donc le discriminateur veut éviter cette faute.

1.4 Quand  $P(w_2) = 10P(w_1)$ , on voit plus de points réel de class  $C_2$ ,  $N_{1,2} + N_{2,2} + N_{3,2}$  devient plus grand. La surface qui est contourné par les discriminateur dans le cas Bayes est plus grand. Car  $P(w_2) = 10P(w_1)$  signifie qu'un  $x$  est plus possible d'appartenir à  $w_2$  a priori.

2.1 La performance du discriminateur de Bayes représenté en nombres sont identique avec la figure 3 qui signifie des coefficients de corrélation entre les images de chiffre 'i' et 'j'. Quand le nombre dans figure 2 est plus grand (en trace), le carré de figure 3 est plus noir.

2.2 On voit que  $R$  Bayes est constante, parce qu'il est équivalent a le cas de  $\mu$  et  $\Gamma$  connue, et  $R$  des deux autre courbes diminue selon  $P_{app}$  augmente et ils convergent vers le cas  $R$  Bayes, c'est le même cas au TP3, l'un est  $R$ , l'autre est  $\tau_g$ . Et  $R$  de Bayes linéaire est diminué avant le cas quadratique, fonctionne meilleur. Mais ma question est que on n'est pas sûr la raison. Peut-être selon  $P_{app}$  augmente  $\tau_g$  sont proche pour les différents chiffres et  $P_{gen}$  sont le même, donc  $\Gamma$  sont presque égales, correspond au cas linéaire.

2.3 Quand on veut diminuer l'influence sur  $R$ , on voit que le coefficient de corrélation de  $N_{8,8}$  diminue, c'est à dire que quand on utilise le risque de Bayes, si on veut diminuer l'influence des chiffres ressemblants, comme on augmente  $a_{6,8}$  pour obtenir  $N_{6,8}$  plus petit, ça veut d'autres coefficients de corrélation.

3.1 D'après les coefficients de corrélation, la sommation de  $RN\_kappa$  en trace est plus grande que celle de  $RN\_beta$ , d'où la performance de  $RN\_kappa$  est mieux que celle de  $RN\_beta$  où dans la matrice du coût il y a un grand nombre 100 dans cette colonne. Le risque de  $RN\_beta$  est plus petit, d'après l'histogramme, mais ils sont tous plus petit que celle de  $RN$ . Quand la base d'apprentissage augmente, par exemple  $P_{app} = 10000$ , les performances tendent vers la même limitation, ils sont presque pareille.

3.2 Quand on change la fonction coût, ( $choix - cout = 3$ , dans la matrice des coûts, il n'y a pas des grands nombres sauf la dernière colonne avec des nombres 10), les performances et les risques des deux  $RN$  sont presque pareilles. Quand on change le prior, l'endroit où le prior est très peu est moins possible d'avoir un point estimé. Les performances et les risques des deux  $RN$  sont presque les mêmes, car le prior cache la différence générée par la matrice des coûts.

3.3 Comme on a fait dans le TP, on ajoute un paramètre  $A$  pour générer une base où l'amplitude est inconnue. Ici, on propose à ajouter plusieurs paramètres  $[a_{i,j}]$ ,  $[b_i]$  qui représentent la matrice des coûts inconnus et la colonne du prior inconnu. Et on détermine une l'intervalle où les paramètres peuvent bouger au hasard. D'après ce modèle, on régénère la base d'apprentissage avec un grand  $P_{app}$  qui assure l'assurance. Et on utilise cette base à effectuer l'apprentissage. (on n'est pas sûr est-ce que ça peut marcher ou pas. Il faut un grand nombre de  $P_{app}$ .)